

SVEUČILIŠTE U SPLITU
EKONOMSKI FAKULTET

ZAVRŠNI RAD

**OBLIKOVANJE OPTIMALNOG MODELA ZA
PREDVIĐANJA BANKROTA U HRVATSKOJ**

Mentor:

Prof. dr. sc. Zlatan Reić

Student:

Borna Krolo

Split, svibanj 2019.

SADRŽAJ

1. UVOD	1
1.1. Problem rada	1
1.2. Cilj rada	1
1.3. Metode rada	1
1.4. Struktura rada	2
2. UTVRĐIVANJE POSLOVNOG NEUPIJEHA NA TEMELJU RAČUNOVODSTVENIH INFORMACIJA IZ FINACIJSKIH IZVJEŠTAJA	3
2.1. Temeljna financijska izvješća	3
2.1.1. Bilanca	4
2.1.2. Račun dobiti i gubitka	5
2.1.3. Izvještaj o novčanom tijeku	5
2.1.4. Izvještaj o promjenama kapitala	5
2.1.5. Bilješke	6
2.2. Financijski pokazatelji	6
2.2.1. Pokazatelj likvidnosti	6
2.2.2. Pokazatelji zaduženosti	8
2.2.3. Pokazatelji aktivnosti	8
2.2.4. Pokazatelji ekonomičnosti	9
2.2.5. Pokazatelji profitabilnosti	10
2.2.6. Pokazatelji investiranja	10
2.3. Poznati modeli ocjene rizičnosti poduzeća	11
2.3.1. Beaverov model	11
2.3.2. Almantov Z score model	12
2.3.3. Kralicekov model	13
2.3.4. Deakinov model	13
2.4.5. Chesser model	14
2.3.6. Zmijewski model	14
2.4. Najznačajniji modeli za predviđanje bankrota i neuspjeha u Hrvatskoj	15
3. PRONALAZAK OPTIMALNOG MODELA	17
3.1. Podatci i metode	17
3.2. Model procjene stečaja poduzeća	27
	2

4. ZAKLJUČAK	31
5. LITERATURA	32
POPIS SLIKA	34
POPIS TABLICA	34
SAŽETAK	36
SUMMARY	36

1. UVOD

1.1. Problem rada

Informacije o poslovanju poduzeća sadržane su u financijskim izvješćima. Financijska izvješća mogu služiti za interne potrebe društva ili pak kao temelj potencijalnim suradnicima i investitorima. Financijska izvješća su nužna kod procjene likvidnosti, efektivnosti, profitabilnosti i drugih poslovnih parametrima poduzeća. Financijska izvješća pak sadrže podatke koji su potrebni za izračun financijskih pokazatelja.

Bankrot poduzeća slijed je nemogućnosti podmirenja obveza poduzeća prema vjerovnicima. Razlozi bankrota su razni: nelikvidnost, prezaduženosti, nesposobnost plaćanja, itd. Poslovni neuspjeh se može odraziti na zapošljavanje, rast poduzeća, krizu i u krajnjem slučaju stečaj (bankrot) poduzeća.

1.2. Cilj rada

Cilj ovog završnog rada je razvijanje modela za predviđanje bankrota na osnovu podataka iz financijskih izvješća 31 poduzeća.

1.3. Metode rada

Prilikom izrade rada primijenjene su sljedeće metode:¹

- metoda analize – raščlanjivanje složenih misaonih tvorevina na jednostavnije
- metoda deskripcije – postupak jednostavnog opisivanja ili ocrtavanja činjenica, procesa i predmeta te njihovih empirijskih potvrđivanja odnosa i veza,
- metoda klasifikacije – podjela općih pojmova na posebne,
- metoda komparacije – uspoređivanje istih ili srodnih činjenica, pojava i procesa,
- metoda sinteze – spajanje jednostavnih misli, sudova ili zaključaka u složene,
- metoda indukcije – donošenje općeg suda temeljem pojedinačnih ili posebnih činjenica,
- metoda dedukcije – donošenje posebnih, pojedinačnih sudova temeljem općih stavova.

1.4. Struktura rada

Rad je podijeljen u 4 cjeline uključujući uvod i zaključak. Nakon uvoda, u drugom dijelu rada

¹ Zelenika, R. (2000): Metodologija i tehnologija izrade znanstvenog i stručnog djela. Ekonomski fakultet Rijeka, Rijeka, str. 309-402.

je obrađen koncept temeljnih financijskih izvještaja te njihova važnost u prikazu računovodstvenih informacija. U nastavku drugog dijela rada se govori o teorijskim aspektima financijskih pokazatelja i njihovoj primjeni u ocjeni rizičnosti poduzeća. Drugo poglavlje završava teorijskim okvirom izabranih poznatih modela za predviđanje financijske nestabilnosti kako u svijetu tako i u Republici Hrvatskoj. Treći dio rada je empirijski dio gdje se temeljem podataka iz financijskih izvještaja 30 poduzeća prezentira poslovanje izračunom određenih financijskih pokazatelja. Zadnji dio je zaključak.

2. UTVRĐIVANJE POSLOVNOG NEUPIJEHA NA TEMELJU RAČUNOVODSTVENIH INFORMACIJA IZ FINANCIJSKIH IZVJEŠTAJA

Poslovni subjekti s poslovanjem na području Republike Hrvatske obavezni i u skladu s Zakonom o računovodstvu voditi poslovne knjige. Poduzeća kreiraju svoja poslovna izvješća na temelju kojih i interni i eksterni korisnici imaju dostupne informacije o poslovanju poduzeća na osnovu kojih donose poslovne odluke.

Prema Zakonu o računovodstvu poduzeća se dijele na mikro, male, srednje i velike poduzetniku ovisno o kriterijima navedenim u tablici 1. Poduzetnici spadaju u onu skupinu u kojoj ne prelaze granične pokazatelje u dva od tri uvjeta.²

Tablica 1: Poduzetnici prema Zakonu o računovodstvu

VELIČINA	Mikro	Mala	Srednja	Velika
Aktiva	2.600.00 kn	30.000.000 kn	150.000.000 kn	150.000.000 kn
Prihod	5.200.000 kn	60.000.000 kn	300.000.000 kn	300.000.000 kn
Prosječan broj zaposlenih	10	50	250	250

Izvor: Narodne novine (2018): Zakon o računovodstvu, Narodne novine, Zagreb, članak 5.

2.1. Temeljna financijska izvješća

Poduzeća su dužna izraditi i javno prikazati na Internet stranicama FINA-e i sudskog registra svoja godišnja financijska izvješća. Cilj financijskih izvještaja je "pružiti informacije o financijskom položaju, uspješnosti poslovanja i promjenama financijskog položaja subjekta, što je korisno krugu korisnika u donošenju ekonomskih odluka. Financijski izvještaji sastavljeni za tu svrhu udovoljavaju uobičajenim potrebama većine korisnika."³

U temeljena financijska izvješća spadaju⁴:

- Izvještaj o financijskom položaju (bilanca)
- Račun dobiti i gubitka
- Izvještaj o ostaloj sveobuhvatnoj dobiti

² Narodne novine (2018): Zakon o računovodstvu, Narodne novine, Zagreb, članak 5.

³ Narodne novine (2009): Međunarodni računovodstveni standard 1: Prezentiranje financijskih izvještaja, točka 9, Narodne novine, Zagreb, broj 136.

⁴ Narodne novine (2018): Zakon o računovodstvu, Narodne novine, Zagreb, članak 19, st. 2.

- Izvještaj o novčanim tijekovima
- Izvještaj o promjenama kapitala
- Bilješke uz financijske izvještaje.

2.1.1. Bilanca

Bilanca je financijski izvještaj koji daje pregled u imovinu, obveze i kapital poduzeća na određeni datum. Bilanca daje uvid u kategorije imovine i iznose imovine koja se koristi u poduzeću te istodobno s njim nastale obaveze poduzeća prema zajmodavcima i vlasnicima.⁵ Poduzeća koja su strukturom veća i poduzeća koja kotiraju na burzi su dužna bilancu sastavljati kvartalno unutar poslovne godine.

Tablica 2: Struktura bilance

AKTIVA	PASIVA
DUGOTRAJNA IMOVINA	KAPITAL I REZERVE
1. nematerijalna imovina 2. materijalna imovina 3. dugotrajna financijska imovina 4. dugoročna potraživanja 5. odgođena porezna imovina	1. temeljni kapital 2. kapitalne rezerve 3. rezerve iz dobit 4. revalorizacijske rezerve 5. zadržana dobit 6. dobit ili gubitak poslovne godine 7. manjinski interes
KRATKOTRAJNA IMOVINA 1. zalihe 2. potraživanja 3. kratkotrajna financijska imovina 4. novac u banci i blagajni	REZERVIRANJA
	DUGOROČNE OBVEZE
	KRATKOROČNE OBVEZE
PLAĆENI TROŠKOVI BUDUĆEG RAZDOBLJA I OBRAČUNATI PRIHODI	ODGOĐENO PLAĆANJE TROŠKOVA I PRIHOD BUDUĆEG RAZDOBLJA
GUBITAK IZNAD KAPITALA	

Izvor: izrada autora

Bilanca se sastoji od aktive koju čini imovina te pasive koju čine kapital i obveze.⁶ Aktiva bilance je podijeljena u dvije grupe: dugotrajnu imovinu (sa dugim vijekom trajanja) i

⁵ Helfert, Erich A. (1997.): Tehnike financijske analize, Hrvatska zajednica računovođa i financijskih djelatnika, Zagreb, str. 14

⁶ Vujević I. (2009.): Analiza financijskih izvještaja, ST-Tisak, Split, str. 35.

kratkotrajnu imovinu (tekuća ili obrtna imovina). Kapital je vlastiti izvor financiranja imovine poduzetnika i on predstavlja ostatak imovine nakon podmirenja obveza. Obveze mogu biti kratkoročne i dugoročne. Dugoročne obveze su obveze čiji je rok dospijeca veći od 12 mjeseci, dok je kod kratkoročnih obveza kraći od 12 mjeseci.

2.1.2. Račun dobiti i gubitka

Račun dobiti i gubitka prikazuje prihode i rashode poduzeća te financijski rezultat za određeni obračunski period. Onaj tip financijskog izvještaja donosi informacije o profitabilnosti poduzeća te o njegovoj učinkovitosti korištenja resursa. Temeljni elementi koje sadrži račun dobiti u gubitka su prihod, rashod, dobit prije oporezivanja, porez na dobit te neto dobit (dobit poslije oporezivanja).

Prihodi su rezultat povećanja imovine ili smanjenja obveza u obračunskom razdoblju. Prihodi mogu biti redovni te izvanredni. Rashodi se također dijele na redovne i izvanredne te oni predstavljaju smanjenje ekonomske koristi kroz promatrano razdoblje.⁷ Ukoliko su prihodi poduzeća veći od rashoda poduzeće posluje s dobiti, dok je u suprotnom riječ o poslovanju s gubitkom.

Izvještaj o ostaloj sveobuhvatnoj dobiti je dio računa dobiti i gubitka obveznika koji koriste Međunarodne standarde financijskog izvještavanja.

2.1.3. Izvještaj o novčanom tijeku

Izvještaj o novčanom tijeku pokazuje priljeve i odljeve novca za promatrano razdoblje od jedne godine. Glavne kategorije izvještaja o novčanom tijeku su novac i novčani ekvivalenti. Izvještaj o novčanom tijeku ukazuje na to kakvo bi bilo poslovanje kada bi se obračun temeljio na priljevu i odljevu novca, a ne prema nastanku događaja.

Primici i izdaci se u izvještaju o novčanom toku svrstavaju u tri grupe⁸:

- Poslovne aktivnosti,
- Investicijske aktivnosti i
- Financijske aktivnosti.

⁷ Žager, K., Žager, L.(2008): Analiza financijskih izvještaja, MASMEDIA, Zagreb, str. 70-71.

⁸ D. Gulini i sur. (2006): Računovodstvo trgovačkih društava, Hrvatska zajednica računovođa i financijskih djelatnika, Zagreb, str.732.

2.1.4. Izvještaj o promjenama kapitala

Izvještaj o promjenama kapitala daje uvid u promjene neto vrijednosti tvrtke, točnije s bogatstvom dioničara.⁹ Ovaj tip izvještaja se sastavlja za određeno obračunsko razdoblje a najčešće za godinu dana.

2.1.5. Bilješke

Bilješke daju dodatna pojašnjenja za informacije koje nisu izravno vidljive iz temeljnih izvještaja a nužne su za bolje razumijevanje i uvid u poslovanje.¹⁰

2.2. Financijski pokazatelji

Temeljni financijski izvještaji sadrže podatke koji se koriste za izračun pokazatelja poslovanja određenog poduzeća. Analiza poslovanja poduzeća pomoću financijskih pokazatelja je najčešće korištena metoda koja daje pregled i uvid u snage i slabosti poduzeća.

Financijski pokazatelji se mogu podijeliti s obzirom na vremensku dimenziju na dvije skupine: jedna skupina obuhvaća razmatranje poslovanja unutar određenog razdoblja koje je najčešće godinu dana i koristi podatke iz izvještaja o dobiti, dok se druga odnosi na promatranje poslovanja u točno određenom trenutku koji se podudara s trenutkom sastavljanja bilance.¹¹

Najčešće korištena klasifikacija financijskih pokazatelja je¹²:

- Pokazatelji likvidnosti
- Pokazatelji zaduženosti
- Pokazatelji aktivnosti
- Pokazatelji ekonomičnosti
- Pokazatelji profitabilnosti
- Pokazatelji investiranja

⁹ Vujević, I. (2009): Analiza financijskih izvještaja, ST-tisak, Split, str. 64.

¹⁰ Žager, K., Žager L., (2008): Analiza financijskih izvještaja, MASMEDIA, Split, str.89.

¹¹ Žager, K., Žager L., (2008): Analiza financijskih izvještaja, MASMEDIA, Zagreb, str. 243.

¹² Vukoja, B. : Primjena analize financijskih izvješća pomoću ključnih financijskih pokazatelja kao temelj donošenja poslovnih odluka, Internet, raspoloživo na: <http://www.revident.ba/public/files/primjena-analize-financijskihizvjestaja-pomocu-kljucnih-financijskih-pokazatelja.pdf> [25.3.2019.]

2.2.1. Pokazatelj likvidnosti

Postizanje likvidnosti je jedan od glavnih ciljeva poduzeća. Likvidnost podrazumijeva raspoloživa sredstva kada su potrebna kao i u slučaju žurnih i iznenadnih potreba.¹³

Pokazatelji likvidnosti su mjere sposobnosti društva da podmiri svoje kratkoročne obveze.

Najčešće korišteni pokazatelji likvidnosti su¹⁴:

- Koeficijent trenutne likvidnosti
- Koeficijent ubrzane likvidnosti
- Koeficijent tekuće likvidnosti
- Koeficijent financijske stabilnosti

U tablici 3 su prikazani načini računanja navedenih pokazatelja likvidnosti.

Tablica 3: Pokazatelji likvidnosti

Pokazatelj	Brojnik	Nazivnik
Koeficijent trenutne likvidnosti	Novac	Kratkoročne obveze
Koeficijent ubrzane likvidnosti	Kratkotrajna imovina – zalihe	Kratkoročne obveze
Koeficijent tekuće likvidnosti	Kratkotrajna imovina	Kratkoročne obveze
Koeficijent financijske stabilnosti	Dugotrajna imovina	Kapital + dugoročne obveze

Izvor: Žager, K., Žager, L. (2008): Analiza financijskih izvještaja, MASMEDIA, Zagreb, str.248.

Pri financijskoj analizi za potrebe ovog završnog rada koristit će se koeficijent tekuće likvidnosti, koeficijent ubrzane likvidnosti te koeficijent financijske stabilnosti. Koeficijent tekuće likvidnosti se dobiva kao omjer kratkotrajne imovine i kratkoročnih obveza te ukazuje na sigurnost podmirenja svih tekućih obveza. Koeficijent tekuće likvidnosti bi trebao biti veći od 2, točnije kratkotrajna imovina bi trebala biti najmanje dvostruko veća od kratkoročnih obveza.¹⁵

Koeficijent ubrzane likvidnosti je omjer zbroja novca i potraživanja i kratkoročnih obveza. Vrijednost koeficijenta ubrzane likvidnosti ne bi trebala odstupati značajno od 1. Ovaj

¹³ Sorić, I. (2002): Analiza povezanosti između poslovnog rezultata i likvidnosti, Ekonomski pregled, Hrvatsko društvo ekonomista, Zagreb, str. 560.

¹⁴ Žager, K., Žager, L. (2008): Analiza financijskih izvještaja, MASMEDIA, Zagreb, str.248

¹⁵ Ibidem, str. 249

pokazatelj ukazuje na to ima li poduzeće dovoljno kratkoročnih sredstava kako bi podmirilo dospjele obveze a da ne prodaje zalihe.

Koeficijent financijske stabilnosti je omjer knjigovodstvene vrijednosti dugotrajne imovine i kapitala uvećanog za iznos dugoročnih obveza. Ukoliko je koeficijent financijske stabilnosti manja od 1 znači da se kratkotrajna imovina financira dijelom iz dugoročnih izvora, a ukoliko je veći od 1 znači da se dugotrajna imovina financira iz kratkoročnih obveza.¹⁶

2.2.2. Pokazatelji zaduženosti

Pokazatelji zaduženosti računaju se na temelji podataka preuzetih iz bilance. Oni ukazuju na strukturu kapitala i načine financiranja imovine poduzeća. Najčešće korišteni pokazatelji zaduženosti su¹⁷:

- Pokazatelj zaduženosti
- Pokazatelj vlastitog financiranja
- Pokazatelj financiranja
- Pokazatelj pokrića kamata
- Faktor zaduženosti
- Stupanj pokrića I
- Stupanj pokrića II

Koeficijent zaduženosti predstavlja omjer ukupnih obveza poduzeća i ukupne imovine. Njegova vrijednost bi trebala biti 50% ili manja. Koeficijent vlastitog financiranja je omjer glavnice i ukupne imovine, te ukazuje na to koliko je imovine financirano iz vlastitog kapitala. Njegova vrijednost bi trebala biti veća od 50%. Koeficijent financiranja je omjer ukupnih obveza poduzeća te kapitala i rezervi. Ukoliko je koeficijent financiranja manji od 1 poduzeće koriti u većoj mjeri vlastite izvore financiranja.

Navedeni pokazatelji ukazuju na strukturu kapitala društva na datum sastavljanja bilance te je ona temeljna za ocjenjivanje zaduženosti društva. Pokazatelji zaduženosti daju informacije o stupnju zaduženosti poduzeća, ali ne i o kvaliteti posuđenih izvora financiranja što znači da se

¹⁶ Ibidem

¹⁷ Vukoja, B. : Primjena analize financijskih izvješća pomoću ključnih financijskih pokazatelja kao temelj donošenja poslovnih odluka, Internet, raspoloživo na: <http://www.revident.ba/public/files/primjena-analize-financijskihizvjestaja-pomocu-kljucnih-financijskih-pokazatelja.pdf> [25.3.2019.]

u analizu trebaju uključiti i drugi pokazatelji poput pokazatelja profitabilnosti.¹⁸

2.2.3. Pokazatelji aktivnosti

Pokazatelji aktivnosti se temelje na računanju odnosa prometa i prosječnog stanja te su poznati o pod nazivom koeficijent obrtaja. Oni predstavljaju mjere učinkovitosti korištenja vlastitih resursa kao i brzinu cirkuliranja imovine u poslovnom procesu. Podaci za računanje pokazatelja aktivnosti se uzimaju iz bilance te računa dobiti i gubitka.

Najčešće korišteni pokazatelji aktivnosti su koeficijent obrtaja ukupne imovine, koeficijent obrtaja dugotrajne imovine, koeficijent obrtaja potraživanja te dani naplate potraživanja. U tablici 4 su navedeni pokazatelji te njihov način računanja.

Tablica 4: Pokazatelji aktivnosti

Pokazatelj	Brojnik	Nazivnik
Koeficijent obrtaja ukupne imovine	Ukupni prihod	Ukupna imovina
Koeficijent obrtaja kratkotrajne imovine	Ukupni prihod	Kratkotrajna imovina
Koeficijent obrtaja potraživanja	Prihod od prodaje	Potraživanja
Dani naplate potraživanja	Broj dana u godini (365)	Koeficijent obrtaja potraživanje

Izvor: Žager i sur. (2008): Analiza financijskih izvještaja, str. 252, Zagreb.

Koeficijent obrtaja imovine ukazuje koliko se puta ukupna imovina poduzeća obrne u tijeku jedne godine, točnije koliko uspješno poduzeće koristi imovinu kako bi stvorilo prihod. Ukoliko je aktivnost obrtaja imovine veći, veća je i aktivnost društva. Koeficijent obrtaja kratkotrajne imovine ukazuje na to koliko puta se kratkotrajna imovina poduzeća obrne u tijeku jedne godine te on mjeri relativnu efikasnost kojom poduzeće koristi kratkotrajnu imovinu s ciljem stvaranja prihoda. Koeficijent obrtaja potraživanja utvrđuje prosječno trajanje naplate potraživanja, dok trajanje naplate potraživanja mjeri vrijeme koje je potrebno kako bi se prosječna prodaja pretvorila u novac.

¹⁸ Ježovita, A., i Tager, L. (2014): Ocjena zaduženosti poduzeća pokazateljima profitabilnosti, Zbornik Ekonomskog fakulteta u Zagrebu, Sveučilište u Zagrebu: Ekonomski fakultet Zagreb, Zagreb, str.2.

2.2.4. Pokazatelji ekonomičnosti

Pokazatelji ekonomičnosti su mjere odnosa prihoda i rashoda poduzeća te ukazuju koliko se prihoda ostvaruje po jedinici rashoda. Podaci za izračun ovih pokazatelja se uzimaju iz računa dobiti i gubitka. Poželjno je da pokazatelji ekonomičnosti budu što veći.

Tablica 5: Pokazatelji ekonomičnosti

Pokazatelj	Brojnik	Nazivnik
Ekonomičnost ukupno poslovanja	Ukupni prihodi	Ukupni rashodi
Ekonomičnost poslovnih aktivnosti	Prihod od prodaje	Rashod od prodaje
Ekonomičnost financiranja	Financijski prihodi	Financijski rashodi

Izvor: Bolfek i sur. (2012): Vertikalna i horizontalna financijska analiza poslovanja tvrtke. Ekonomski vjesnik, Sveučilište Josipa Jurja Strossmayera u Osijeku: Ekonomski fakultet u Osijeku, Osijek, str. 162.

2.2.5. Pokazatelji profitabilnosti

Analiza profitabilnosti uključuje dvije temeljne mjere: profitnu maržu i povrat na investirano. Pokazatelji profitabilnosti mjere sposobnost poduzeća da ostvaruje dobit u odnosu na ostvarene prihode, imovinu ili kapital.

Tablica 6: Pokazatelji profitabilnosti

Pokazatelj	Brojnik	Nazivnik
Neto profitna marža	Neto dobit + kamate	Ukupni prihod
Bruto profitna marža	Dobit prije poreza + kamate	Ukupni prihod
Neto rentabilnost imovine	Neto dobit + kamate	Ukupna imovina
Bruto rentabilnost imovine	Dobit prije poreza + kamate	Ukupna imovina
Rentabilnost glavnice	Neto dobit	Glavnica

Izvor: Žager i sur. (2008): Analiza financijskih izvještaja, str. 253, Zagreb.

Marža profita mjeri rentabilnost prometa i dobiva se omjerom zbroja neto dobiti i kamata i prihoda od prodaje. Ona ukazuje na to koliko se dobiva neto dobiti na ukupnim prihodima. Bruto profitna marža ukazuje na rezultate prije oporezivanja.

Stopa povrata imovine ROA (neto rentabilnost imovine) je mjera profitabilnosti omjera neto dobiti i kamata te ukupne imovine. Veći pokazatelj potvrđuje i veću profitabilnost.

Rentabilnost vlastitog kapitala (REO) ukazuje na to koliko se na jednu jedinicu glavnice

ostvaruje jedinica dobiti. Veća vrijednost pokazatelja ukazuje na to da je poduzeće uspješnije, ali može ukazivati i na zaduženost i pad kamatnih stopa.

2.2.6. Pokazatelji investiranja

Pokazatelji investiranja ukazuju na uspješnost investiranja u dionice društva. Za izračunavanje pokazatelja su potrebni i podaci o dionicama.

U najznačajnije pokazatelje investiranja spadaju¹⁹:

- Dobit po dionici predstavlja odnos neto dobiti i broja dionica. U pravilu je dobit po dionici veća od dividende po dionici.
- Dividenda po dionici pokazuje ostvareni iznos u kunama koji se ostvaruje od dividende po jednoj dionici.
- Odnos isplate dividendi stavlja u odnos dividendu i dobiti po pojedinoj dionici. Taj pokazatelj je najčešće manji od 1, jer je po pravilu zarada po dionici veća od dividenda po dionici iz razloga što se dio dobiti zadržava.
- Odnos cijena i dobiti po dionici upućuje na povećanje tržišne cijene ili dobiti po dionici.
- Ukupna rentabilnost dionice pokazuje odnos između dobiti po dionici i tržišne cijene dionice.
- Dividenda rentabilnost dionice predstavlja prinos po dividendi, pa se stavlja u odnos dividendu po dionici i tržišnu vrijednost te dionice.

Unutar završnog rada biti će napravljena financijska analiza koristeći pokazatelje prikazane u tablici 7.

Tablica 7: Pokazatelji poslovanja

Pokazatelj	Brojnik	Nazivnik
Koeficijent tekuće likvidnost	Kratkotrajna imovina	Kratkoročne obveze
Koeficijent ubrzane likvidnosti	Kratkotrajna imovina – zalihe	Kratkoročne obveze
Stupanj zaduženost	Ukupne obveze	Ukupna imovina
Koeficijent financijske stabilnosti	Dugotrajna imovina	Glavnica + dugoročne obveze

¹⁹ Žager, K. i Žager, L. (1999): Analiza financijskih izvještaja. Zagreb: MASMEDIA, str. 180.

Dani vezivanja potražnje	Broj dana u godini (365)	Koeficijent obrtaja potraživanja
Dani vezivanja obveza	365	Prihod od prodaje / Dugovanje prema dobavljačima
Neto profitna marža	Neto dobit + kamate	Ukupni prihod
ROA	Neto dobit	Ukupna imovina
ROE	Neto dobit	Glavnica

Izvor: obrada autora prema Žager i sur. (2008): Analiza financijskih izvještaja, Zagreb.

2.3. Poznati modeli ocjene rizičnosti poduzeća

2.3.1. Beaverov model

Prvi model za ocjenjivanje rizičnosti poduzeća je predstavio 1996. godine William H. Beaver koji smatra da je poduzeće poslovno neuspješno ukoliko je nesposobno da podmiri dospelje financijske obveze.²⁰ Svoj model je Beaver definirao na uzorku od 158 proizvodnih poduzeća čijima se dionicama javno trgovali i koja su bila iz 38 različitih industrija. Beaverli je izračunao 30 financijskih pokazatelja koji su bili grupirani u 6 skupina. Pokazatelje je odabrao temeljem njihove učestalosti spominjanja u literaturi, relevantnosti pokazatelja u definiranju poslovnog neuspjeha te pripadnosti pokazatelja skupini temeljenoj na novčanom tijeku.²¹ Dokazano je da financijski neuspjeh najbolje predviđaju sljedeći pokazatelji:

- Tijek novca / Ukupna imovina
- Čisti prihod / Ukupni dug
- Tijek novca / Ukupni dug.

2.3.2. Altmanov Z score model

Altman Z'score mjeri vjerojatnost odlaska poduzeća u stečaj. Kombinacijom pet različitih financijskih pokazatelja dobiva se vrijednost koja sugerira koliko je poslovanje poduzeća ugroženo. Vrijednost iznad 3 sugerira kako je poduzeće zdravo, te ima malu vjerojatnost ulaska u stečajni postupak. Vrijednost ispod 1,8 označava veliku vjerojatnost ulaska poduzeća u stečajni postupak, dok vrijednosti između 1,8 i 3 označavaju diskutabilnu situaciju u poslovanju poduzeća. Altman je proveo analizu na uzorku računajući 22 financijska

²⁰ Beaver, W. (1966): Financial Ratios as Predictors of Failure, Journal of Accounting Research, Supplement, Vol. 4 Issue 3, str. 71

²¹ Ibidem, str. 78.

pokazatelja. Altman je razvio model koji se iskazuje sljedećom jednačicom²²:

$$Z=0,012X_1 + 0,014X_2 + 0,033X_3 + 0,006X_4 + 0,999X_5 \quad (1)$$

Gdje je:

X_1 = radni kapital / ukupna aktiva

X_2 = zadržana dobit / ukupna aktiva

X_3 = operativna dobit (EBIT) / ukupna aktiva

X_4 = tržišna vrijednost glavnice / ukupne obveze

X_5 = prihod od prodaje / ukupna aktiva

Godine 1993. dolazi do korekcije originalnog modela kada se varijabli X_4 mijenja tržišna vrijednosti glavnice njenom knjigovodstvenom vrijednosti te zbog toga dolazi do promijene cijelog modela:

$$Z'=0,717X_1 + 0,847X_2 + 3,107X_3 + 0,42X_4 + 0,998X_5 \quad (2)$$

Dolazi i do druge izmjene modela kada se prilagođava predviđanju stečaja neproizvodnih poslovnih subjekata. Iz modela se isključiva varijabla X_5 , te druga modifikacija dovodi do sljedeće jednačice²³:

$$Z''=6,56X_1 + 3,26X_2 + 6,72X_3 + 1,05X_4 \quad (3)$$

2.3.3. Kralicekov model

Kralicekov model je razvijen 2007 godine. Austrijanac Peter Kralicek je razvio model provodeći multivarijantnu analizu. U model je uključio procjenjivanje financijske uspješnosti, likvidnost i stabilnosti poslovanja poduzeća.

Jednačica Kralicek modela glasi²⁴:

$$DF= 1,5X_1 + 0,08X_2 + 10X_3 + 5X_4 + 0,3X_5 + 0,1X_6 \quad (4)$$

²² Šodan S.: Financijska analiza poslovanja, skripta, Split, ak.god. 2015./2016., predavanja br. 10, str. 4.

²³ Zenzerović R., Peruško T. (2006): Kratki osvrt na modele za predviđanje stečaja, Ekonomska istraživanja, Vol 19, str. 143

²⁴ Ibidem, Str. 18.

Gdje je DF vrijednost diskriminantne funkcije

X_1 čisti novčani tok (EBIT + amortizacija/(ukupne obaveze)

X_2 ukupna imovina/ukupne obaveze

X_3 dobit prije kamata i poreza/ukupna imovina

X_4 dobit prije kamata i poreza/ukupan prihod

X_5 zalihe/ukupni prihod

X_6 poslovni prihod/ukupna imovina

2.3.4. Deakinov model

Deakin je uočio da su se poduzeća koja je klasificirao kao neuspješna prije bankrota unazad četiri ili pet godina ubrzano počela širiti. Širenje poduzeća je potaknulo povećanje duga i povlaštene dionice. Zbog toga su poduzeća sredstva ulagala u tvornice i opremu a ne u tekuću imovinu. Deakin je također uočio da se omjer novac/prihodi od prodaje bitno razlikuje od drugim omjera koji su bili konzistentni.²⁵ Deakinov model može predvidjeti stečaj s velikom točnošću do prije tri godine prije stečaja temeljem metode diskriminacijske analize, dok s idućim godinama vjerojatnost predviđanja opada.

2.4.5. Chesser model

Chesser model mjeri vjerojatnost da će poduzeće imati probleme u podmirivanju svojih obveza po kreditu. Ukoliko je vrijednost iznad 0,5 dolazi se do zaključka da bi poduzeće moglo imati probleme u podmirenju obveza po kreditu.²⁶

Varijable koje čine model su sljedeće:

X_1 =gotovina/ukupna imovina

X_2 =neto prodaja/gotovina

X_3 =dobit prije oporezivanja/ukupna imovina

X_4 =ukupan dug/ukupna imovina

²⁵ Deakin, E. (1972): A discriminant analysis of predictors of business failure, Journal of accounting research, str. 167

²⁶ Internet, raspoloživo na: <http://www.poslovnahrvatska.hr>, [29.02.2019]

X_5 =dugotrajna imovina/neto vrijednost

X_6 =(kratkotrajna imovina-kratkoročne obveze)/neto prodaja

Model se računa sljedećom formulom²⁷:

$$Y = -2.043 + 5.24X_1 + 0.0053X_2 - 6.6507X_3 + 4.409X_4 - 0.0791X_5 - 0.1020X_6 \quad (5)$$

2.3.6. Zmijewski model

Zmijewski model je razvijen 1984. godine. Zmijewski je koristio pokazatelje za mjerenje uspješnosti poslovanja, zaduženosti i likvidnosti poduzeća na podacima od 800 poduzeća koja nisu bankrotirala i 40 poduzeća koja jesu bankrotirala.²⁸

Multivarijantnom analizom dobiven je sljedeći model²⁹:

$$Y = -4,3 - 4,5X_1 + 5,7X_2 + 0,004X_3 \quad (6)$$

gdje je: X_1 = neto dobit / ukupna imovina

X_2 = ukupni dug / ukupna imovina

X_3 = kratkotrajna imovina / kratkoročne obveze

Ukoliko je vrijednost vjerojatnosti veća od 0,5 smatra se da poduzeće ima velike šanse da završi u stečaju.

2.4. Najznačajniji modeli za predviđanje bankrota i neuspjeha u Hrvatskoj

Jedan od modela za predviđanje bankrota u Hrvatskoj su definirali Pervan I., Pervan M. i Vukoja 2011. godine. Uzorak koji su koristili za potrebe analize se sastojao od 156 poduzeća čije su informacije o poslovanju bile dostupne. Na temelju podataka iz financijskih izvještaja izračunato je 15 financijskih pokazatelja. Izračunali su Pearsonov koeficijent korelacije čime se izbjegao problem multikolinearnosti te je u konačnici određeno 6 financijskih pokazatelja prikazanih u tablici 8.

Tablica 8: Financijski pokazatelji

²⁷ Chesser, D.L. (1974): Predicting loan noncompliance, Journal of commercial bank lending, str. 28-38

²⁸ Šarlija N. (2008): Kreditna analiza, predavanja, Osijek, poglavlje 7, str. 139.

²⁹ Šodan S.: Financijska analiza poslovanja, skripta, Split, ak. god. 2015./2016., predavanja br. 10, str. 5

Pokazatelj	Odnos
Tekuća likvidnosti	Kratkotrajna imovina / Kratkoročne obveze
Neto radni kapital	(Kratkotrajna imovina – kratkoročne obveze) / Kratkotrajna imovina
Pokazatelj tekuće imovine	Tekuća imovina / Ukupna imovina
Poluga	Ukupne obveze / Ukupna imovina
Pokazatelj obrtaja imovine	Prihodi od prodaje / Ukupna imovina
EBIT	EBIT / Ukupna imovina

Izvor: Pervan, I., et al. (2011): Prediction of company bankruptcy using statistical techniques – case of Croatia, Croatian Operational Research Review (CRORR), Vol. 2, str. 163

Konačni model nakon analize glasi:

$$\text{FP RATING}^{\circledR} = -1,0937 + 2,0956X_1 - 0,005X_2 + 0,6220X_3 - 0,000005X_4 + 0,1116X_5 \quad (7)$$

Gdje je: X_1 stupanj samofinanciranja

X_2 faktor zaduženost

X_3 obrtaj ukupne imovine

X_4 vrijeme naplate potraživanja

X_5 novčani operativni potencijal.

Pervan i Kuvek su definirali model koristeći i nefinancijske varijable kao što su kvaliteta financijskih izvještaja, kreditni bonitet vlasnika i kvaliteta uprave. Prvo je postavljen model izračuna samo s financijskim vrijednostima, te je nakon toga i model i s financijskim i nefinancijskim varijablama kako bi se usporedili. Model sa financijskim varijablama je pokazao 88,4% točnu klasifikaciju kod zdravih trgovačkih društava dok je kod neuspješnih trgovačkih društava točnost bila 52%. Drugi model s nefinancijskim varijablama je rezultirao s 92,4% točnosti klasifikacije uspješnih poduzeća, dok je kod neuspješnih poduzeća točnost bila 64,6%.³⁰

Ivčić i Cerovac provode analizu na uzorku od 7 719 poduzeća. Koristili su 84 financijska pokazatelja koja su odabrana prema kriteriju uspješnosti predviđanja neuspješnosti podmirenja obveza. Financijski pokazatelji su grupirani u sljedeće grupe:

³⁰ Pervan, I. i Kuvek, T. (2013.) The relative importance of financial ratios and nonfinancial variables in predicting of insolvency, Croatian Operational Research Review, Vol. 3. str. 187-197.

1. Pokazatelja likvidnosti (mjerenoga kao gotovina prema ukupnoj imovini)
2. Pokazatelja vlastitog financiranja (dionički kapital prema ukupnoj imovini)
3. Pokazatelja aktivnosti (promet potraživanja od kupaca u danima)
4. Dva pokazatelja profitabilnosti (zarada prije oporezivanja i kamata prema ukupnim obvezama te prodaja i amortizacija prema ukupnoj imovini).

Model glasi³¹:
$$F[\beta, t] = 1 / (1 + e^{-(0,17 - 0,28 D_{i,t} - 0,63 w_{1,10i,t} - 0,63 w_{1,10i,t} - 1,96 w_{2,2i,t} + 0,09 w_{3,4i,t} - 0,1 w_{5,16i,t} - 0,37 w_{5,22i,t} - 0,01 w_{7,5i,t})}) \quad (8)$$

Model je točno klasificirao 74,4% poduzeća koja uredno podmiruju obveze te 71,2% poduzeća koja ne podmiruju obveze.

Šarlija i suradnici kreiraju model za predviđanje kratkoročne nelikvidnosti. Nelikvidno poduzeće je definirano kao poduzeće čiji je žiro račun u blokadi tri mjeseca i više u kontinuitetu. Uzorak je sadržavao 75 145 trgovačkih društava ne uključujući banke, štedionice i osiguranja. Izračunao je 29 financijskih pokazatelja, s konačnim modelom od 16 varijabli. Uz financijske varijable bile su uvrštene djelatnosti i županija kao nezavisne varijable. Modelom je dokazano da su za previđanje nelikvidnosti važni financijski pokazatelji: likvidnost, zaduženost, aktivnost, ekonomičnost i profitabilnost. Također je modelom dokazao da postoji razlika u likvidnosti poduzeća s obzirom na djelatnost kojom se bave i županiju.³²

³¹ Ivičić, L., Cerovac, S. (2009): Procjena kreditnog rizika poduzeća u Hrvatskoj, Financijska teorija i praksa 33 (4), str. 385-413

³² Šarlija, N., Penavin, S., Harc, M. (2009): Pregledni rad: Predviđanje nelikvidnosti poduzeća u Hrvatskoj, Zbornik Ekonomskog fakulteta u Zagrebu, br.2, str. 21-36.

3. PRONALAZAK OPTIMALNOG MODELA

3.1. Podatci i metode

Za potrebe empirijskog dijela ovog rada pristupljeno je portalu Poslovna.hr³³, te e oglasnoj ploči Hrvatskog pravosuđa.³⁴

Završni računi u Republici Hrvatskoj kod poslovanja pravnih osoba se predaju na poreznu upravu zaključno sa 30.04. tekuće godine za prethodnu godinu.³⁵

Zadnja dostupna financijska izvješća odnose se na poslovanje u 2017. godini, zbog čega je godina analize uzeta 2017 godina.

Za potrebe ovog rada uzet je velik uzorak, koji je prema Rozga (2017) uzorak koji prelazi 30 jedinica promatranja, zbog čega je uzet uzorak od 31. poduzeća od čega je 16 poduzeća sa urednim poslovanje, te 15 poduzeća koja su proglasila stečaj u razdoblju od 01.05.2018 do 31.06.2018 (drugi kvartal). Poduzeća su odabrana na slučajan način.

U radu se koriste metoda grafičkog i tabelarnog prikazivanja, metode deskriptivne statistike, Mann-Whitney U test, Pearsonova korelacija, te Logistički regresijski model.

Metodama grafičkog i tabelarnog prikazivanja prezentira se poslovanje odabranih poduzeća. Primjenom metoda deskriptivne statistike prezentiraju se numeričke vrijednosti kao i odstupanja od srednjih vrijednosti.

Razlika u vrijednostima među promatranim skupinama poduzeća testira se Mann-Whitney U testom, dok se povezanost među vrijednostima odabranih pokazatelja testira Pearsonovm korelacijom.

Utjecaj odabranih varijabli na objavu stečaja testira se upotrebom Logističke regresije.

Analiza se radi u statističkom programu SPSS 22.

³³ Internet, raspoloživo na: <http://www.poslovnahrvatska.hr>, [29.02.2019]

³⁴ Internet, raspoloživo na: <https://e-oglasna.pravosudje.hr/?q=stečaj/9934>, [29.02.2019]


³⁵ Internet, raspoloživo na: <https://www.porezna-uprava.hr>, [29.02.2019]

Tablica 9: Uzorak poduzeća

Stečaj u 2017	Naziv poduzeća	Godina
da	Dječji vrtić loptica u stečaju	2017
da	Panonija d.d. Osijek u stečaju	2017
da	Toz penkala, tvornica olovaka Zagreb d.d. u stečaju	2017
da	Petrinčica dom d.o.o. u stečaju	2017
da	Divero d.o.o.	2017
da	Una acceptus d.o.o. u stečaju	2017
da	Dk d.o.o. u stečaju	2017
da	Krička d.o.o. u stečaju	2017
da	Global sistem d.o.o., veliko trojstvo	2017
da	Eol ing d.o.o. u stečaju	2017
da	Istra porta d.o.o. u stečaju	2017
da	Komodeca d.o.o. u stečaju	2017
da	Konavle d.o.o.	2017
da	Apozito turizam d.o.o. u stečaju	2017
da	Blue yachts d.o.o. u stečaju	2017
ne	Auto-kuća kovačić d.o.o.	2017
ne	Lovret d.o.o.	2017
ne	Neir d.o.o.	2017
ne	Prizmić d.o.o.	2017
ne	Čale-auto d.o.o.	2017
ne	Pristan d.o.o.	2017
ne	Argatin d.o.o.	2017
ne	Sretna obitelj d.o.o.	2017
ne	Vima d.o.o.	2017
ne	Romb d.o.o.	2017
ne	Eko-tim d.o.o.	2017
ne	Adamas d.o.o.	2017
ne	Fistonić d.o.o.	2017
ne	Croatia yachting d.o.o.	2017
ne	Propter d.o.o.	2017
ne	Kuzmanić yachting d.o.o.	2017

Izvor: obrada autora

Slika 1: Struktura poduzeća prema postojanju stečaja



Izvor: obrada autora

Prema postojanju stečaja poduzeća može se utvrditi da 16 poduzeća (51,6%) bilježi uredno poslovanje, dok je 15 poduzeća (48,39%) objavilo stečaj.

Tablica 10: Financijski pokazatelji

Puni naziv	Oznaka	Jedinica mjere	Izvor	Očekivan utjecaj na nezavisnu varijablu
Stečaj	Stečaj	Ne = 0 Da = 1	Poslovna.hr	/
Ukupno aktiva	log.akt		Poslovna.hr	-
Koeficijent tekuće likvidnosti	teklik		Poslovna.hr	-
Koeficijent ubrzane likvidnosti	ubrzlik		Poslovna.hr	-
Stupanj zaduženosti	zad		Poslovna.hr	+
Koeficijent financijske stabilnosti prvog stupnja	kfst1		Poslovna.hr	-
Koeficijent financijske	kfst2		Poslovna.hr	-

stabilnosti drugog stupnja				
Dani vezivanja potražnje	dpotr		Poslovna.hr	+
Dani vezivanja obveza	dobv		Poslovna.hr	+
Neto profitna marža	NPV		Poslovna.hr	-
ROE	ROE		Poslovna.hr	-
ROA	ROA		Poslovna.hr	-
Altman Z Score	Altman Z Score		Poslovna.hr	-
Chesser model	Chesser model		Poslovna.hr	+
Zmijewski model				+

Izvor: obrada autora

Nakon odabira varijabli prezentiraju se razlike u pokazateljima upotrebom metoda deskriptivne statistike.

Tablica 11: Deskriptivna statistika

	Sva poduzeća			Poduzeća s urednim poslovanjem			Poduzeća u stečaju		
	Altman Z Score	Chesser model	Zmijewski model	Altman Z Score	Chesser model	Zmijewski model	Altman Z Score	Chesser model	Zmijewski model
Prosjek	2,26	0,62	0,55	4,19	0,59	0,42	0,20	0,70	0,71
Medijan	2,10	0,71	0,59	2,57	0,71	0,41	0,24	0,79	0,95
Mod	2,24	1,00	1,00	2,24	1,00	0,20	-34,18b	1,00	1,00
St. dev.	9,76	0,35	0,38	3,73	0,35	0,33	13,43	0,37	0,39
Minimum	-34,18	0,06	0,01	0,16	0,06	0,01	-34,18	0,08	0,05
Maksimum	28,60	1,00	1,00	14,15	1,00	1,00	28,60	1,00	1,00

Izvor: obrada autora

Iz tablice deskriptivne statistike se može utvrditi da je prosječna vrijednost Altman Z score pokazatelja 2,26 uz postojanje velike disperzije vrijednosti Altman Z score vrijednosti u promatranom uzorku poduzeća (SD=9,96) iz čega se može utvrditi da je primjerenije koristiti medijan kao srednju vrijednost. Srednja vrijednost medijan kod svih promatranih poduzeća je 2,10, dok je kod poduzeća koja uredno posluju 2,57, te kod poduzeća koja su objavila stečaj 0,24.

Srednje vrijednosti kod Chesser modela i Zmijewski modela su veće kod poduzeća koja su objavila stečaj u odnosu na vrijednosti kod poduzeća koja uredno posluju. Razlika u vrijednostima testirana je Mann-Whitney U testom.

Slika 2: Mann Whitney U test

Hypothesis Test Summary			
	Null Hypothesis	Test	Sig. Decision
1	The distribution of Altman Z Score is the same across categories of Stečaj.	Independent-Samples Mann-Whitney U Test	,002 ¹ Reject the null hypothesis.
2	The distribution of Chesser model is the same across categories of Stečaj.	Independent-Samples Mann-Whitney U Test	,424 ¹ Retain the null hypothesis.
3	The distribution of Zmijewski model is the same across categories of Stečaj.	Independent-Samples Mann-Whitney U Test	,041 ¹ Reject the null hypothesis.

Asymptotic significances are displayed. The significance level is ,10.

¹Exact significance is displayed for this test.

Izvor: obrada autora

Na temelju empirijske vrijednosti 0,002 donosi se zaključak da postoji statistički značajna razlika u vrijednosti Altman Z score među poduzećima koja uredno posluju i poduzećima koja su objavila stečaj, odnosno može se donijeti zaključak da će poduzeća koja uredno posluju imati i statistički značajno veću vrijednost Altman Z score pokazatelja.

Statistički značajna razlika je utvrđena i za Zmijewski model (emp. $p = 0,041$), odnosno utvrđeno da je da poduzeća koja uredno posluju imaju statistički značajno manju Zmijewski model vrijednost u odnosu na poduzeća koja su objavila stečaj.

Razlika u Chesser model vrijednosti nije utvrđena (empirijska p vrijednost 0,424).

Tablica 12: Deskriptivna statistika

Sva poduzeća								
	Akt	teklik	ubrzli k	zad	kfst1	kfst2	Dpotr	dobv
Prosjek	10.411.000,00	36,63	2,08	6,11	36,36	-21,67	4.868,27	11.860,07
Medijan	1.361.400,00	1,09	0,71	0,84	1,02	0,76	56,00	163,00
St. dev.	27.843.740,83	186,55	5,43	24,17	352,04	118,66	18.825,4 5	35.056,31
Minimum	5.600,00	0,00	0,00	0,03	-638,47	-638,47	0,00	2,00
Maksimu m	148.768.000,00	1.041,0 0	29,90	135,5 7	1.685,30	4,59	85.932,0 0	149.368,0 0
Uredna poduzeća								
Prosjek	9.908.912,50	70,31	3,34	0,75	2,66	1,26	65,98	80,00
Medijan	2.204.000,00	1,57	1,32	0,67	1,43	1,19	40,00	51,00
St. dev.	13.864.395,66	259,04	7,25	0,56	6,62	1,13	58,92	80,36
Minimum	42.800,00	0,57	0,29	0,03	-7,05	-1,04	0,00	2,00
Maksimu m	44.487.000,00	1041,00	29,90	2,39	24,86	3,03	151,00	250,00
Poduzeća u stečaju								
Prosjek	10.946.560,00	0,72	0,65	11,84	78,48	-49,89	12672,00	25323,00
Medijan	861.400,00	0,31	0,32	1,21	0,46	0,43	282,00	1496,50
St. dev.	38.141.240,57	0,97	0,99	34,41	537,94	176,88	30002,18	48739,08
Minimum	5.600,00	0,00	0,00	0,24	-638,47	-638,47	0,00	10,00
Maksimu m	148.768.000,00	3,83	3,83	135,5 7	1685,30	4,59	85932,00	149368,00

Izvor: obrada autora

Srednja vrijednost aktive (medijan) je kod promatranog uzorka poduzeća 1.361.400,00 gdje je utvrđena veća vrijednost kod poduzeća koja uredno posluju u odnosu na poduzeća u stečaju.

Poduzeća koja uredno posluju bilježila su vrijednosti promatranih pokazatelja bliže referentnima u odnosu na poduzeća koja su objavila stečaj, pa tako poduzeća koja su objavila stečaju su imala niže vrijednosti pokazatelja tekuće i ubrzane likvidnosti, nižu vrijednosti koeficijenata financijske stabilnosti 1 i 2. Više vrijednosti u odnosu na poduzeća koja uredno posluju bilježena su za vrijeme naplate potraživanja, vrijeme plaćanja obveza, te veću zaduženost.

Postojanje statistički značajnih razlika testira se Mann-Whitney U testom.

Slika 3: Mann Whitney U test

Hypothesis Test Summary				
	Null Hypothesis	Test	Sig.	Decision
1	The distribution of log.akt is the same across categories of Stečaj.	Independent-Samples Mann-Whitney U Test	,093 ¹	Reject the null hypothesis.
2	The distribution of teklik is the same across categories of Stečaj.	Independent-Samples Mann-Whitney U Test	,000 ¹	Reject the null hypothesis.
3	The distribution of ubrzlik is the same across categories of Stečaj.	Independent-Samples Mann-Whitney U Test	,002 ¹	Reject the null hypothesis.
4	The distribution of zad is the same across categories of Stečaj.	Independent-Samples Mann-Whitney U Test	,008 ¹	Reject the null hypothesis.
5	The distribution of kfst1 is the same across categories of Stečaj.	Independent-Samples Mann-Whitney U Test	,025 ¹	Reject the null hypothesis.
6	The distribution of kfst2 is the same across categories of Stečaj.	Independent-Samples Mann-Whitney U Test	,009 ¹	Reject the null hypothesis.
7	The distribution of dpotr is the same across categories of Stečaj.	Independent-Samples Mann-Whitney U Test	,456 ¹	Retain the null hypothesis.
8	The distribution of dobv is the same across categories of Stečaj.	Independent-Samples Mann-Whitney U Test	,000 ¹	Reject the null hypothesis.

Asymptotic significances are displayed. The significance level is ,10.

¹Exact significance is displayed for this test.

Izvor: obrada autora

Empirijske p vrijednosti manje od 0,10 utvrđene su kod testiranja razlika u svim odabranim parametrima kvalitete poslovanja poduzeća izuzev dana vezivanja potraživanja gdje je utvrđena empirijska p vrijednost 0,456. Dakle, postoji statistički značajna razlika u vrijednostima svih promatranih varijabli među poduzećima koja uredno posluju i poduzećima u stečaju izuzev broja dana vezivanja potraživanja.

Tablica 13: Pokazatelji uspješnosti poslovanja

	Sva poduzeća			Poduzeća s urednim poslovanjem			Poduzeća u stečaju		
	NPV	ROE	ROA	NPV	ROE	ROA	NPV	ROE	ROA
Prosjek	-30,92	76,91	39,59	7,24	28,42	15,30	-74,53	128,63	65,51
Medijan	3,25	7,80	3,00	3,25	13,45	5,70	1,19	1,80	-0,90
Mod	-1151,83a	-176,50a	3,00a	,16b	-4,90b	3,00b	1151,83b	176,50b	174,00b
St. dev.	214,80	272,76	181,02	12,00	57,19	32,65	314,51	387,78	260,15
Minimum	-1.151,83	-176,50	174,00	0,16	-4,90	1,30	-1151,83	-176,50	-174,00
Maksimum	79,35	1.451,80	870,60	48,99	237,60	135,80	79,35	1451,80	870,60

Izvor: obrada autora

Promatrajući pokazatelje uspješnosti poslovanja može se utvrditi da su poduzeća u stečaju bilježila niže vrijednosti sva 3 odabrana pokazatelja uspješnosti (neto profitnu maržu, povrat na imovinu te povrat na kapital) u odnosu na poduzeća koja uredno posluju.

Slika 4: Mann Whitney U test

Hypothesis Test Summary				
	Null Hypothesis	Test	Sig.	Decision
1	The distribution of NPV is the same across categories of Stečaj.	Independent-Samples Mann-Whitney U Test	,918 ¹	Retain the null hypothesis.
2	The distribution of ROE is the same across categories of Stečaj.	Independent-Samples Mann-Whitney U Test	,175 ¹	Retain the null hypothesis.
3	The distribution of ROA is the same across categories of Stečaj.	Independent-Samples Mann-Whitney U Test	,006 ¹	Reject the null hypothesis.

Asymptotic significances are displayed. The significance level is ,10.

¹Exact significance is displayed for this test.

Izvor: obrada autora

Na temelju empirijske p vrijednosti 0,006 može se utvrditi da postoji statistički značajno veća vrijednost ROA pokazatelja uspješnosti među poduzećima koja uredno posluju u odnosu na poduzeća u stečaju. Razlika u vrijednostima neto profitne marže i ROE pokazatelju uspješnosti nije utvrđena (empirijske p vrijednosti > 0,10).

Početni model glasi:

Stečaj = f (aktiva, pokazatelj tekuće likvidnosti, pokazatelj ubrzane likvidnosti, zaduženost, koeficijent financijske stabilnosti 1, koeficijent financijske stabilnosti 2, dani vezivanja potraživanja, dani vezivanja obveza, neto profitna marža, povrat na imovinu, povrat na kapital, Altman Z score, Chesser model, povrat na aktivu).

Da bi model davao adekvatne rezultate nužan uvjet je otklanjanje potencijalnog problema multikolinearnosti.

Prvi korak detekcije navedenog problema je provjera korelacije među nezavisnim varijablama.

Tablica 14: Korelacija

		Akt	teklik	ubrzli k	zad	kfst1	kfst2	dpotr	dobv	NPV	ROE	ROA
Akt	r	1										
	p											
	n	31										
teklik	r	-0,051	1									
	p	0,392										
	n	31	31									
ubrzli k	r	-0,064	-0,019	1								
	p	0,368	0,46									
	n	30	30	30								
zad	r	-0,088	-0,046	-0,094	1							
	p	0,319	0,403	0,31								
	n	31	31	30	31							
kfst1	r	-0,029	-0,007	0	-,388*	1						
	p	0,444	0,487	0,499	0,023							
	n	27	27	26	27	27						
kfst2	r	0,077	0,039	0,079	-,998**	,390*	1					
	p	0,347	0,419	0,345	0	0,022						
	n	29	29	28	29	27	29					
dpotr	r	-0,095	-0,058	-0,021	-0,093	,987**	,465*	1				

	p	0,341	0,401	0,464	0,344	0	0,022					
	n	21	21	21	21	19	19	21				
dobv	r	-0,103	-0,068	-0,116	-0,035	-0,036	0,057	,772**	1			
	p	0,295	0,36	0,275	0,426	0,431	0,387	0				
	n	30	30	29	30	26	28	21	30			
NPV	r	0,069	0,031	0,04	0,095	-0,025	-0,095	-0,251	0,117	1		
	p	0,358	0,435	0,418	0,309	0,452	0,316	0,136	0,273			
	n	30	30	29	30	26	28	21	29	30		
ROE	r	-0,082	-0,052	-0,055	-0,058	-0,034	0,058	-0,083	-0,101	0,006	1	
	p	0,331	0,39	0,387	0,379	0,433	0,382	0,36	0,298	0,486		
	n	31	31	30	31	27	29	21	30	30	31	
ROA	r	-0,073	-0,041	-0,055	,837**	-,349*	-,858**	-0,03	-0,063	0,141	-0,149	1
	p	0,347	0,413	0,387	0	0,037	0	0,449	0,371	0,229	0,212	
	n	31	31	30	31	27	29	21	30	30	31	31

Izvor: obrada autora

Iz tablice se može utvrditi postojanje statistički značajne jake negativne povezanosti između pokazatelja zaduženosti i koeficijenta financijske stabilnosti 2, jake pozitivne povezanosti između koeficijenta financijske stabilnosti 1 i dana vezivanja potraživanja. Dani vezivanja potraživanja statistički značajno su pozitivno i umjereno povezani sa danima vezivanja obveza.

Financijski pokazatelj uspješnosti je statistički značajno pozitivno jako povezan s kretanjem financijskog pokazatelja zaduženosti, te negativno povezan s financijskim pokazateljem koeficijentom financijske stabilnosti 2.

Tablica 15: Korelacija

Correlations			Stečaj	Altman Z Score	Chesser model	Zmijewski model
Spearman's rho	Stečaj	Correlation Coefficient	1,000	-,541**	,193	,396*
		Sig. (1-tailed)	.	,001	,201	,019
		N	31	31	21	28
	Altman Z Score	Correlation Coefficient	-,541**	1,000	-,353	-,414*
		Sig. (1-tailed)	,001	.	,058	,014
		N	31	31	21	28
	Chesser model	Correlation Coefficient	,193	-,353	1,000	,821**
		Sig. (1-tailed)	,201	,058	.	,000
		N	21	21	21	20
	Zmijewski	Correlation	,396*	-,414*	,821**	1,000

model	Coefficient				
	Sig. (1-tailed)	,019	,014	,000	.
	N	28	28	20	28

** . Correlation is significant at the 0.01 level (1-tailed).

* . Correlation is significant at the 0.05 level (1-tailed).

Izvor: obrada autora

Povezanost između financijskih ocjena stabilnosti poslovanja utvrđeno je postojanje statistički značajne negativne povezanosti između proglašenja stečaja i Altman Z score vrijednosti ($r = -0,541$; emp. $p = 0,001$), te proglašenja stečaja i Zmijewski model vrijednosti.

3.2. Model procjene stečaja poduzeća

Tablica 16: Test koeficijenta

Omnibus Tests of Model Coefficients				
	Chi-square	df	Sig.	
Step	30,278	3	,000	
Step 1 Block	30,278	3	,000	
Model	30,278	3	,000	

Izvor: obrada autora

Upotrebom logističke regresijske utvrđen je utjecaj dana vezivanja obveza prema dobavljaču i Altman Z Score na stečaj poduzeća. Empirijska vrijednost Hi kvadrata 30,278 pri 3 stupnja slobode upućuje na zaključak da je model kao cjelina statistički značajan (empirijska p vrijednost $< 0,001$).

Tablica 17: Model

Model Summary			
Step	-2 Log likelihood	Cox & Snell R Square	Nagelkerke R Square
1	9,614 ^a	,648	,867

a. Estimation terminated at iteration number 15 because parameter estimates changed by less than ,001.

Izvor: obrada autora

Cox & Snell R Square i **Nagelkerke R Square** predstavljaju pokazatelje protumačenosti varijacije kretanja od strane odabranih nezavisnih varijabli. U ovom modelu protumačenost se kreće u rasponu od 64,8% do 86,7%. Riječ je o zadovoljavajućim vrijednostima promatranog

kriterija.

Binomna logistička regresija procjenjuje vjerojatnost događanja zavisne varijable. Ukoliko vrijednost prelazi 0,50 može se klasificirati postojanje utjecaja odabranih nezavisnih varijabli na objavu stečaja poduzeća.

Binomnu logističku regresiju je primjereno koristiti ukoliko se testira utjecaj varijabli koje se pojavljuju u barem 2 oblika na zavisnu varijablu koja se događa ili ne događa (vrijednosti 1 ili 0). Adekvatna je metoda procjene utjecaja odabranih nezavisnih varijabli na objavu stečaja poduzeća. Razdioba stvarnih i modelskih objavljivanja stečaja prikazuje se u klasifikacijskoj tablici koja služi i kao temelj za ocjenu reprezentativnosti procijenjenog modela.

Tablica 18: Klasifikacija

Classification Table ^a				
	Observed	Predicted		
		Stečaj		Percentage Correct
		0	1	
Step 1	Stečaj 0	14	2	87,5
	Stečaj 1	1	12	92,3
	Overall Percentage			89,7

a. The cut value is ,500

Izvor: obrada autora

Vrijednost 89,7% upućuje na zaključak da u 89,7% slučajeva procijenjeni model će adekvatno prikazati utjecaj nezavisnih varijabli na zavisnu koja je u ovom slučaju objavljivanje stečaja.

Senzitivnost (osjetljivost) modela predstavlja situaciju kada će procijenjeni model prikazati utjecaj ukoliko isti zapravo postoji, te je u navedenom slučaju riječ o 12 od 13 slučajeva (92,3%), odnosno riječ je o ispravno pozitivnim rezultatima. U 14 od 16 slučajeva model će procijeniti nepostojanje objave stečaja ako isti zapravo i nije objavljen (specifičnost = 87,5%).

Tablica 19: Varijable

Variables in the Equation								
	B	S.E.	Wald	df	Sig.	Exp(B)	95% C.I. for EXP(B)	
							Lower	Upper
Step 1 ^a								
dobv	,046	,026	3,212	1	,073	1,047	,996	1,101
AltmanZScore	,121	,095	1,645	1	,200	1,129	,938	1,359
ubrzlik	-5,113	2,958	2,988	1	,084	,006	,000	1,983
Constant	-3,032	1,974	2,359	1	,125	,048		

a. Variable(s) entered on step 1: dobv, AltmanZScore, ubrzlik.

Izvor: obrada autora

Statistička značajnost procijenjenih parametara dobivena je upotrebom Wald testa

Nakon procjene modela utvrđen je statistički značajan utjecaj:

- Pokazatelj vezivanja obveza prema dobavljačima (emp. $p=0,073$) pri razini signifikantnosti od 10% i
- Koeficijent ubrzane likvidnosti (emp. $p=0,084$) pri razini signifikantnosti od 10%.

Utjecaj promjene pokazatelja Alrman Z score nije utvrđen (emp. $p=0,200$).

Procijenjena vrijednost parametra uz dane vezivanja dobavljača 1,047 znači da svakim dodatnim danom vezivanja obveza prema dobavljačima povećava se šansa za objavu stečaja za 4,7%.

Vrijednost parametra -0,006 uz varijablu veličina znači da porast vrijednosti koeficijenta ubrzane likvidnosti za jednu jedinicu smanjuje šansu da bude objavljen stečaj za 99,4%.

Utjecaj ostalih varijabli na iskazivanje podataka o novčanom toku nije statistički značajan (empirijske p vrijednosti $> 0,05$).

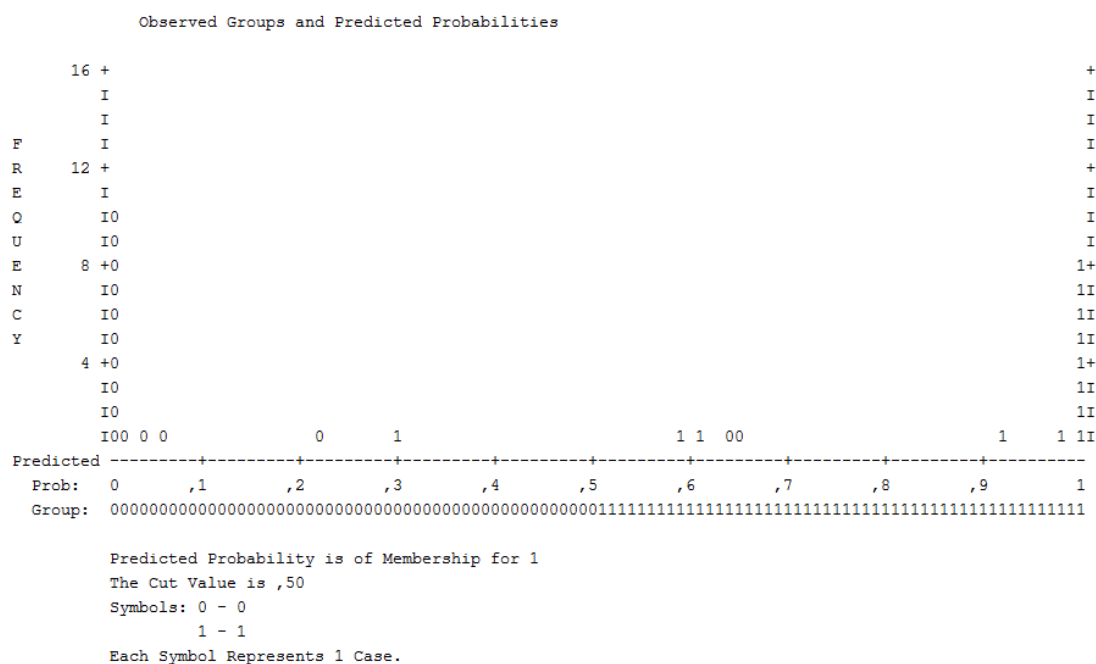
Tablica 20: Korelacija

Correlations				
		ubrzlik	dobv	Altman Z Score
ubrzlik	Pearson Correlation	1	-,116	,071
	Sig. (1-tailed)		,275	,355
	N	30	29	30
dobv	Pearson Correlation	-,116	1	-,139
	Sig. (1-tailed)	,275		,232
	N	29	30	30
Altman Z Score	Pearson Correlation	,071	-,139	1
	Sig. (1-tailed)	,355	,232	
	N	30	30	31

Izvor: obrada autora

Iz tablice korelacije se može utvrditi da kretanje vrijednosti nezavisnih varijabli u modeli nije povezano, zbog čega se može problem multikolinearnosti eliminirati iz procijenjenog modela.

Slika 5: Grafički prikaz kretanja vjerojatnosti objave stečaja



Izvor: obrada autora

Iz grafičkog prikaza se može utvrditi da najveći broj poduzeća ima nisku vjerojatnost objave stečaja.

4. ZAKLJUČAK

Nakon obavljenog testiranja utvrđeno je da poduzeća koja su objavila stečaj su imala manje vrijednosti Altman Z score pokazatelja, te veće vrijednosti Zmijewski model pokazatelja.

Prema poslovnim financijskim pokazateljima poslovanja utvrđena je veća vrijednost aktive kod poduzeća sa urednim poslovanjem u odnosu na poduzeća koja su objavila stečaj.

Poduzeća koja uredno posluju bilježila su vrijednosti promatranih pokazatelja bliže referentnima u odnosu na poduzeća koja su objavila stečaj, pa tako poduzeća koja su objavila stečaju su imala niže vrijednosti pokazatelja tekuće i ubrzane likvidnosti, nižu vrijednosti koeficijenata financijske stabilnosti 1 i 2. Više vrijednosti u odnosu na poduzeća koja uredno posluju bilježena su za vrijeme naplate potraživanja, vrijeme plaćanja obveza, te veću zaduženost.

Dani vezivanja potraživanja nisu se statistički značajno razlikovala među poduzećima koja uredno posluju i poduzećima koja su objavila stečaj.

statistički značajno veća vrijednost ROA pokazatelja uspješnosti među poduzećima koja uredno posluju u odnosu na poduzeća u stečaju. Razlika u vrijednostima neto profitne marže i ROE pokazatelju uspješnosti nije utvrđena.

Upotrebom logističke regresije testiran je utjecaj odabranih pokazatelja na objavu stečaja, te je utvrđeno da poduzeća sa većim danima vezivanja obveza, te sa nižim vrijednostima pokazatelja ubrzane likvidnosti imaju veću vjerojatnost objave stečaja.

5. LITERATURA

1. Beaver, W. (1966): Financial Ratios as Predictors of Failure, Journal of Accounting Research, Supplement, Vol. 4 Issue 3.
2. Bolfek i sur. (2012): Vertikalna i horizontalna financijska analiza poslovanja tvrtke. Ekonomski vjesnik, Sveučilište Josipa Jurja Strossmayera u Osijeku: Ekonomski fakultet u Osijeku, Osijek.
3. D. Gulin i sur. (2006): Računovodstvo trgovačkih društava, Hrvatska zajednica računovođa i financijskih djelatnika, Zagreb.
4. Deakin, E. (1972): A discriminant analysis of predictors of business failure, Journal of accounting research.
5. Helfert, Erich A. (1997.): Tehnike financijske analize, Hrvatska zajednica računovođa i financijskih djelatnika, Zagreb.
6. Ivičić, L., Cerovac, S. (2009): Procjena kreditnog rizika poduzeća u Hrvatskoj, Financijska teorija i praksa 33 (4).
7. Ježovita, A., i Tager, L. (2014): Ocjena zaduženosti poduzeća pokazateljima profitabilnosti, Zbornik Ekonomskog fakulteta u Zagrebu, Sveučilište u Zagrebu: Ekonomski fakultet Zagreb, Zagreb.
8. Narodne novine (2009): Međunarodni računovodstveni standard 1: Prezentiranje financijskih izvještaja, točka 9, Narodne novine, Zagreb, broj 136 .
9. Narodne novine (2018): Zakon o računovodstvu, Narodne novine, Zagreb, članak 5.
10. Pervan, I. i Kuvek, T. (2013.) The relative importance of financial ratios and nonfinancial variables in predicting of insolvency, Croatian Operational Research Review, Vol. 3.
11. Pervan, I., et al. (2011): Prediction of company bankruptcy using statistical techniques – case of Croatia, Croatian Operational Research Review (CRORR), Vol. 2.
12. Rozga, A. (2017) Statistika za ekonomiste, Efst
13. Sorić, I. (2002): Analiza povezanosti između poslovnog rezultata i likvidnosti, Ekonomski pregled, Hrvatsko društvo ekonomista, Zagreb.
14. Šarlija, N., Penavin, S., Harc, M. (2009): Pregledni rad: Predviđanje nelikvidnosti poduzeća u Hrvatskoj, Zbornik Ekonomskog fakulteta u Zagrebu, br.2.
15. Šodan S.: Financijska analiza poslovanja, skripta, Split, ak.god. 2015./2016., predavanja br. 10.

16. Vujević I. (2009.): Analiza financijskih izvještaja, ST-Tisak, Split.
17. Vukoja, B. : Primjena analize financijskih izvješća pomoću ključnih financijskih pokazatelja kao temelj donošenja poslovnih odluka, Internet, raspoloživo na: <http://www.revident.ba/public/files/primjena-analize-financijskihizvjestaja-pomocu-kljucnih-financijskih-pokazatelja.pdf> [25.3.2019.]
18. Zenzerović R., Peruško T. (2006): Kratki osvrt na modele za predviđanje stečaja, Ekonomska istraživanja, Vol 19.
19. Žager, K., Žager L., (2008): Analiza financijskih izvještaja, MASMEDIA, Split.

Ostalo:

20. www.e-oglasna.pravosudje.hr
21. www.porezna-uprava.hr
22. www.poslovna.hr

POPIS SLIKA

Slika 1: Struktura poduzeća prema postojanju stečaja

Slika 2: Mann Whitney U test

Slika 3: Mann Whitney U test

Slika 4: Mann Whitney U test

Slika 5: Grafički prikaz kretanja vjerojatnosti objave stečaja

POPIS TABLICA

Tablica 1: Poduzetnici prema Zakonu o računovodstvu

Tablica 2: Struktura bilance

Tablica 3: Pokazatelji likvidnosti

Tablica 4: Pokazatelji aktivnosti

Tablica 5: Pokazatelji ekonomičnosti

Tablica 6: Pokazatelji profitabilnosti

Tablica 7: Pokazatelji poslovanja

Tablica 8: Financijski pokazatelji

Tablica 9: Uzorak poduzeća

Tablica 10: Financijski pokazatelji

Tablica 11: Deskriptivna statistika

Tablica 12: Deskriptivna statistika

Tablica 13: Pokazatelji uspješnosti poslovanja

Tablica 14: Korelacija

Tablica 15: Korelacija

Tablica 16: Test koeficijenta

Tablica 17: Model

Tablica 18: Klasifikacija

Tablica 19: Varijable

Tablica 20: Korelacija

POPIS FORMULA

1. Altman model
2. Prva modifikacija Altmanovog modela
3. Druga modifikacija Altmanovog modela
4. Kralicek model
5. Chesser model
6. Zmijewski model
7. Model nakon analize
8. Model po uzoru na Ivčić i Cerovac

SAŽETAK

U ovom radu upotrebom financijskih pokazatelja poslovanja kreiran je model predviđanja bankrota poduzeća u Hrvatskoj. Analiza je rađena na uzorku od 31 poduzeća od čega je nad 15 pokrenut stečaj, dok nad 16 nije pokrenut stečaj.

U radu je testiran utjecaj vrijednosti aktive, koeficijenta tekuće likvidnosti, koeficijenta ubrzane likvidnosti, stupnja zaduženosti, koeficijenta financijske stabilnosti prvog stupnja, te koeficijenta financijske stabilnosti drugog stupnja, dana vezivanja potraživanja, dana vezivanja obveza, neto profitne marže, povrata na kapital, povrata na ukupnu imovinu, Altman Z score, Chasser modela i Zmijevski modela na stečaj poduzeća.

Nakon provedenog testiranja utvrđen je utjecaj dana vezivanja dobavljača, vrijednosti Altman Z Score i ubrzane likvidnosti na otvaranje stečaja poduzeća. Utjecaj Altman Z Score i dana vezivanja obveza prema dobavljaču je pozitivan, odnosno utječu na porast vjerojatnosti stečaja dok je utjecaj ubrzane likvidnosti negativan, odnosno povećanje razine ubrzane likvidnosti umanjuje vjerojatnost stečaja.

Ključne riječi: bankrot, stabilnost, financijski pokazatelji

SUMMARY

In this paper, using the financial indicators of the business. We created a model for predicting bankruptcy of companies in Croatia was created. The analysis was performed on a sample of 31 companies, of which 15 were bankrupt, while 16 were bankrupt.

In this working paper We tested the impact of assets, current liquidity ratio, accelerated liquidity ratio, indebtedness ratio, first degree financial stability coefficient, and second degree financial stability coefficient, claims payday, payday, net profit margin, return on equity, Total Assets, Altman Z Score, Chasser Model and Serpent Model Bankruptcy Company. After testing, the impact of supplier bonding days, the value of the Altman Z Score and accelerated liquidity on the opening of bankruptcy was determined. The impact of the Altman Z Score and the day on which the trade payables are linked is positive, that is, they increase the likelihood of bankruptcy, while the impact of accelerated liquidity is negative, that is, the increase in the level of accelerated liquidity reduces the likelihood of bankruptcy.

Key words: bankruptcy, stability, financial indicators